


Minería de Datos para economistas y profesionales de negocios

Un viaje en el mundo de los datos sin programación (códigos) con el software Orange. Serán tratados importantes temas como: Técnicas de agrupamiento, modelos predictivos, minería de texto y análisis de imágenes.

Indice del Taller

Introducción e Instalación	3
Image Analytics: Clustering	8
Predecir la elegibilidad de un préstamo	15
Trabajar con Texto	29

Introducción e Instalación



Con la creciente uso de datos, necesitamos herramientas que eliminen la dificultad de realizar operaciones - cálculos con datos. No todos están dispuestos a aprender codificación, aunque quisieran aprender y aplicar la los datos. Aquí es donde una herramienta con un entorno grafico puede ser muy útil.

Orange: La herramienta ideal para principiantes que desean visualizar patrones y entender sus datos sin saber de codificar.

Configurando tu sistema

<https://orange.biolab.si>

y selecciona Download


selecciona tu sistema Windows o Apple OSX

<https://drive.google.com/drive/folders/1OLkd4tZMnjuofLTXOY94EwKs9fhLVT0Z?usp=sharing>


extensión .exe es Windows / dmg es para Apple OSX

Instale la plataforma y configure el directorio de trabajo para que Orange almacene sus archivos.

Ejecutar como administrador su software Orange!




Nos veamos el pantalla de inicio.




Cerrando el pantalla de bienvenida en el X.

Abrimos Options Add-ons ..



Aquí veamos este menú de selección, selecciona **Image Analytics**, y **Text**, y confirmamos con el botón “OK” la instalación de “Add-ons”.



Después de **reiniciar la aplicación** estamos listo para trabajar.

El espacio de trabajo

Así es como se ve la página de inicio de Orange. Los **objetos se mover con "Arrastrar y soltar" (drag y drop)** de caja de herramientas a nuestro proyecto.

Un **widget es el punto de procesamiento básico de cualquier manipulación de datos**.

Puede realizar una serie de acciones en función de lo que elija en el selector de widgets a la izquierda de la pantalla.

The screenshot displays the Orange3 interface. On the left is the 'Data' widget toolbox with various icons for data loading, manipulation, and analysis. The central workspace shows a workflow with three widgets: 'File', 'Data Table', and 'Correlations', connected by 'Data' links. On the right, the 'Data Table' window shows a dataset with 614 instances and 11 features. Below it, the 'Correlations' window displays Pearson correlation coefficients for various variable pairs.

	NegocioPropio	IngresoSolicitante	gresosC
1	No	5849	0
2	No	4583	1508
3	Si	3000	0
4	No	2583	2358
5	No	6000	0
6	Si	5417	4196
7	No	2333	1516
8	No	3036	2504
9	No	4006	1526
10	No	12841	10968
11	No	3200	700
12	?	2500	1840
13	No	3073	8106
14	No	1853	2840
15	No	1299	1086
16	No	4950	0
17	No	3596	0
18	No	3510	0
19	No	4887	0
20	No	2600	3500
21	No	7660	0
22	No	5955	5625

	Pearson correlation	Variables
1	+0.566	IngresoSolicitante, MontoPrestamo
2	+0.188	IngresosCosolicitante, MontoPrestamo
3	-0.117	IngresoSolicitante, IngresosCosolicitante
4	-0.060	IngresosCosolicitante, PlazoPrestamo
5	-0.045	IngresoSolicitante, PlazoPrestamo
6	+0.039	MontoPrestamo, PlazoPrestamo

Un **flujo de trabajo es la secuencia de pasos o acciones es para realizar una tarea en particular**.

Image Analytics: Clustering

Análisis de imágenes: Agrupamiento

Material: **Software Orange**,

Fichero de datos: **Directorio “domestic-animals”, o archivo “domestic-animals.zip”**


Los datos no siempre vienen en una forma de una tabla. También puede ser una colección de texto, grabaciones de audio, materiales de video o incluso imágenes. Sin embargo, las computadoras solo pueden trabajar con números, por lo que para cualquier extracción de datos, necesitamos transformar esos datos no estructurados en una representación vectorial.

Para recuperar números de datos no estructurados, Orange se puede incrustar en la red. Acabamos de comenzar a incluir varios modulus en Orange, que están disponibles para texto e imágenes.

Aquí, damos un ejemplo de incrustación de imagen y mostramos lo fácil que es usarlo. Técnicamente, Orange enviaría la imagen al servidor, donde el servidor empujaría una imagen a través de una red neuronal profunda pre-entrenada, como el **Inception v3** de Google. La mayoría de las redes profundas se entrenaban con algún propósito especial en mente. Inception v3, por ejemplo, puede clasificar imágenes en cualquiera de 1000 clases de imágenes. Podemos ignorar la clasificación, considerar la penúltima capa de la red con 2048 nodos (números) y usarla para la representación basada en vectores de la imagen.

Aquí tenemos **19 imágenes de animales domésticos (Directorio “domestic-animals”, o archivo “domestic-animals.zip”)**. Primero, descargue las imágenes y descomprímalas. Luego use el widget Importar imágenes del complemento Image Analytics de Orange y abra el directorio que contiene las imágenes.

Arrastramos **Import Imágenes** a nuestro espacio de trabajo, y con un “doble click” cargamos nuestro directorio con los imágenes previamente descargado.



Instalamos los modulos (wigets) **Image Viewer** y **Data Table**. Podemos visualizar imágenes en el widget Visor de imágenes.

The screenshot displays the Orange3 data mining environment. On the left, the 'Data' widget palette is visible, containing various data processing tools. The main workspace shows a workflow starting with an 'Import Images' widget, which connects to both an 'Image Viewer' widget and a 'Data Table' widget. The 'Image Viewer' widget is open, showing a grid of 15 animal images with their corresponding labels: calf, cat, chick, cow, dog, duck, duckling, foal, goat, goose, hen, horse, kid, lamb, and ox. The 'Data Table' widget is also visible, showing a table of data. The 'Image Viewer' widget has a sidebar with settings: 'Info' (Done: 19 images), 'Image Filename Attribute' (image), 'Title Attribute' (image name), and 'Image Size' (a slider).

Image Analytics: Clustering

Image Viewer

Info
Done: 19 images

Image Filename Attribute
image


Title Attribute
image name

Image Size


calf	cat	chick	cow	dog
duck	duckling	foal	goat	goose
hen	horse	kid	lamb	ox

Con un doble click en **Image Viewer**, se puede ver las imágenes, con **Data Table** la tabla. Completamos nuestra aplicación, como se vea en esta grafica.

Completamos nuestra aplicación como vemos en esta grafica.




Ahora necesitamos configurar nuestra aplicación.




Con un doble click abrimos **Image Embedding** y seleccionamos **Inception v3** y cerramos

En el modulo **Distances** necesitamos seleccionar **Cosine**



En **Hierarchical Clustering** vemos el dendrograma y en el **Image Viewer** los objetos seleccionados en el dendrograma.



¡Imágenes tienen números para calcular!

Predecir la elegibilidad de un préstamo

Material: **Software Orange,**

Fichero de datos: **archivo “Credito-Train-es.csv”**

Importando los archivos de datos

Paso 1: haga clic en la pestaña "Datos" en el menú de selección de widgets y arrastre el widget "Archivo" a nuestro flujo de trabajo en blanco.

Paso 2: Haga doble clic en el widget "Archivo" y seleccione el archivo **"Credito Train es.csv"** para cargar en el flujo de trabajo.

machine-learning-eco-ESTUDIANTE.ows

File Edit View Widget Options Help

Data

File Datasets SQL Table Data Table

Paint Data Data Info Data Sampler Select Columns

Select Rows Rank Correlati... Merge Data

Concatenate... Select by Data Ind... Transpose Randomize

Preproc... Transform Impute Outliers

File

Read data from an input file or network and send a data table to the output.

[more...](#)

File

File: Credito-Train-es.csv

URL:

Info

614 instance(s)
11 feature(s) (2.0% missing values)
Data has no target variable.
2 meta attribute(s)

Columns (Double click to edit)


	Name	Type	Role	Values
3	Educacion	Categorical	feature	Graduado, No_Graduado
4	NegocioPropio	Categorical	feature	No, Si
5	IngresoSolicitante	Numeric	feature	
6	IngresosCosolic...	Numeric	feature	
7	MontoPrestamo	Numeric	feature	
8	PlazoPrestamo	Numeric	feature	
9	HistoraCredito	Categorical	feature	0, 1
10	Area	Categorical	feature	Rural, Semiurban, Urban
11	EstadoPrestamo	Categorical	target	N, S
12	Credito	Text	feature	
13	Dependientes	Text	feature	

Browse documentation datasets

Apply

Ahora, haga doble clic en la **columna EstadoPrestamo** y selecciónela como la **variable de destino (target)**. Haga clic en **Aplicar (Apply)**.


Visualizar nuestros Datos



En este ejemplo usamos el el “**Sieve Diagram**”.

Podemos vea también con “**Data Table**” nuestros datos en forma de tabla.

Creamos nuestro modelo



Modulo Impute

Reemplaza valores desconocidos en los datos.

Entradas

- Datos: entrada de datos
- Alumno: algoritmo de aprendizaje para la imputación.

Salidas

- Datos: conjunto de datos con valores imputados.

Algunos algoritmos y visualizaciones de Orange no pueden manejar valores desconocidos en los datos. Este widget hace lo que los estadísticos llaman imputación: sustituye los valores perdidos por valores calculados a partir de los datos o establecidos por el usuario. La imputación predeterminada es (1-NN)

Más detalles en: [https://en.wikipedia.org/wiki/Imputation_\(statistics\)](https://en.wikipedia.org/wiki/Imputation_(statistics))

Logistic Regression / Regresión logística

El algoritmo de clasificación de regresión logística con LASSO (L1) o Ridge (L2) regularización.

Entradas

- Datos: entrada de datos
- Preprocesador: método (s) de preprocesamiento

Salidas

- Aprendiz (Learner): algoritmo de aprendizaje de regresión logística
- Modelo: modelo entrenado
- Coeficientes: coeficientes de regresión logística.

Regresión logística aprende un modelo de Regresión logística a partir de los datos. Solo funciona para tareas de clasificación.

Mas en: https://es.wikipedia.org/wiki/Regresión_logística

Support Vector Machines – SVM / Máquinas de soporte vectorial

Las máquinas de soporte vectorial asignan entradas a espacios de entidades de dimensiones superiores.

Entradas

- Datos: entrada de datos
- Preprocesador: método (s) de preprocesamiento

Salidas

- Aprendiz (Learner): algoritmo de aprendizaje de regresión lineal
- Modelo: modelo entrenado
- Vectores de soporte: instancias utilizadas como vectores de soporte

La máquina de máquinas de soporte vectorial (SVM) es una técnica de aprendizaje automático que separa el espacio de atributos con un hiperplano, maximizando así el margen entre las instancias de diferentes clases o valores de clase. La técnica a menudo produce resultados de rendimiento predictivo supremos. Orange incorpora una implementación popular de SVM del paquete LIBSVM. Este widget es su interfaz gráfica de usuario.

Para las tareas de regresión, SVM realiza una regresión lineal en un espacio de entidad de alta dimensión utilizando una pérdida insensible a ϵ . Su precisión de estimación depende de una buena configuración de los parámetros C , ϵ y kernel. El widget genera predicciones de clase basadas en una Regresión SVM.

Más en: https://es.wikipedia.org/wiki/Máquinas_de_vectores_de_soporte

Random forest / Bosque Aleatorio

Predecir utilizando un conjunto de árboles de decisión.

Entradas

- Datos: entrada de datos
- Preprocesador: método (s) de preprocesamiento

Salidas

- Aprendiz: algoritmo de aprendizaje al azar del bosque
- Modelo: modelo entrenado


El bosque aleatorio es un método de aprendizaje en conjunto utilizado para la clasificación, regresión y otras tareas. Fue propuesto por primera vez por Tin Kam Ho y posteriormente desarrollado por Leo Breiman (Breiman, 2001) y Adele Cutler.

Random Forest construye un conjunto de árboles de decisión. Cada árbol se desarrolla a partir de una muestra bootstrap a partir de los datos de entrenamiento. Al desarrollar árboles individuales, se dibuja un subconjunto arbitrario de atributos (de ahí el término "Aleatorio"), desde el cual se selecciona el mejor atributo para la división. El modelo final se basa en el voto mayoritario de árboles desarrollados individualmente en el bosque. Se observa en datos con mucho "ruido" no esta preciso.

Random Forest funciona tanto para tareas de clasificación como de regresión.

Más en: https://es.wikipedia.org/wiki/Random_forest

Nuestro Modelo



Test and Score / Prueba y puntuación

Pruebas de algoritmos de aprendizaje en datos.

Entradas


- Datos: entrada de datos
- Datos de prueba: datos separados para la prueba
- Aprendiz: algoritmo (s) de aprendizaje

Salidas

- Resultados de la evaluación: resultados de los algoritmos de clasificación de prueba

El widget prueba los algoritmos de aprendizaje. Se encuentran disponibles diferentes esquemas de muestreo, incluido el uso de datos de prueba separados. El widget hace dos cosas. Primero, muestra una tabla con diferentes medidas de rendimiento del clasificador, como la precisión de la clasificación y el área bajo la curva. En segundo lugar, genera resultados de evaluación, que pueden ser utilizados por otros widgets para analizar el rendimiento de los clasificadores, como el análisis ROC o la matriz de confusión.

La señal del alumno (Learner) tiene una propiedad poco común: se puede conectar a más de un widget para probar a múltiples alumnos (Learner) con los mismos procedimientos.



Method	AUC	CA	F1	Precision	Recall
SVM	0.774	0.808	0.791	0.810	0.808
Logistic Regression	0.771	0.741	0.677	0.784	0.741

AUC: El área bajo ROC* es el área bajo la curva operativa del receptor.

CAL: a precisión de la clasificación es la proporción de ejemplos clasificados correctamente.

F-1: Es un medio armónico ponderado de precisión y recuperación (ver más abajo).

Precision: La precisión es la proporción de verdaderos positivos entre los casos clasificados como positivos, p. Ej. La proporción de Iris virginica correctamente identificada como Iris virginica.

Recall: La recuperación es la proporción de verdaderos positivos entre todas las instancias positivas en los datos, por ejemplo, El número de enfermos entre todos los diagnosticados como enfermos.

* **Receiver operating characteristic curve**, or ROC curve, is a graphical plot that illustrates the diagnostic ability of a binary classifier system as its discrimination threshold is varied. The ROC curve is created by plotting the true **positive rate** against the **false positive rate** at various threshold settings. The **true-positive rate** is also known as **sensitivity, recall or probability of detection in machine learning**.

The **false-positive rate** is also known as the **fall-out or probability** of false

machine-learning-eco-ESTUDIANTE.ows

File Edit View Widget Options Help

Data

- File
- Datasets
- SQL Table
- Data Table
- Paint Data
- Data Info
- Data Sampler
- Select Columns
- Select Rows
- Rank
- Correlati...
- Merge Data
- Concat...
- Select by Data Ind...
- Transpose
- Randomize
- Preproc...
- Transform
- Impute
- Outliers

Confusion Matrix

Display a confusion matrix constructed from the results of classifier evaluations.

[more...](#)

File

Data

Data Table

Sie

Impute

Test & Score

Evaluation Results

Confusion Matrix

Confusion Matrix

Logistic Regression
SVM

Show: Proportion of predicted

		Predicted		
		N	S	Σ
Actual	N	82.5 %	19.6 %	192
	S	17.5 %	80.4 %	422
	Σ	114	actual: S predicted: S	614

Output

☒ Predictions ☐ Probabilities

☒ Send Automatically

Select Correct Select Misclassified Clear Selection

Confusion Matrix / Matriz de confusión

En el campo de la inteligencia artificial una matriz de confusión es una herramienta que permite la **visualización del desempeño de un algoritmo** que se emplea en aprendizaje supervisado. Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real. Uno de los beneficios de las matrices de confusión es que facilitan ver si el sistema está confundiendo dos clases.

		Predicted		
		N	S	Σ
Actual	N	82.5 %	19.6 %	192
	S	17.5 %	80.4 %	422
Σ		114	500	614

	Real negativo	Real positivo
Test negativo	Correcto Positivo	Falso Positivo
Test positivo	Falso Negativo	Correcto Negativo

Ejemplo: Pacientes Sanos y Enfermos

Correcto positivo: el paciente está enfermo y la prueba lo ha indicado correctamente.

Falso negativo: el paciente está enfermo, pero la prueba lo ha clasificado como sano por error.

Falso positivo: el paciente está sano, pero la prueba lo ha clasificado erróneamente como enfermo.

Correcto Negativo: el paciente está sano y la prueba lo ha indicado correctamente.

Detalles: https://en.wikipedia.org/wiki/Confusion_matrix
https://en.wikipedia.org/wiki/Evaluation_of_binary_classifiers

Los Resultados en una tabla

machine-learning-eco-ESTUDIANTE.ows*

File Edit View Widget Options Help

Data

File Datasets SQL Table Data Table

Paint Data Data Info Data Sampler Select Columns

Select Rows Rank Correlati... Merge Data

Concatenate... Select by Data Ind... Transpose Randomize

Preproc... Transform Impute Outliers

Data Table

View the dataset in a spreadsheet.

[more...](#)

File

Data Table

Sieve Diagram

Impute

Logistic Regression

SVM

Test & Score

Evaluation Results

Confusion Matrix

Selected Data → Data

Data Table (1)

Data Table (1)

Info

402 instances

10 features (no missing values)

Discrete class with 2 values (no missing values)

3 meta attributes (0.7% missing values)

Variables

☒ Show variable labels (if present)

☒ Visualize numeric values

☒ Color by instance classes


	EstadoPrestamo	Credito_ID	Dependientes	EstadoPrestamo(SVM)	Sexo
399	S	LP002978	0	S	Female
384	S	LP002917	0	S	Female
382	S	LP002894	0	S	Female
370	S	LP002813	1	S	Female
368	S	LP002804	0	S	Female
365	S	LP002794	0	S	Female
358	S	LP002757	0	S	Female
356	S	LP002753	1	S	Female
355	S	LP002741	1	S	Female
350	S	LP002731	0	S	Female
340	S	LP002670	2	S	Female

Trabajar con Texto Working with Text


Material: **Software Orange**,

Fichero de datos: **grimm-ales-selected.tab** (es parte de software Orange).


Creamos este espacio de trabajo:




Y estos son los configuraciones:



En **Corpus** seleccionamos: **grimm-tales-selected.tab**



La métrica de distancia es en **Distances Cosine**



Ahora tenemos el análisis porque este dos documentos están declarados similares.

Este es solo un ejemplo de analisis de datos ...

